

Universidade de Lisboa  
Instituto de Geografia e Ordenamento do Território



**Extração automática de áreas de recauchutagem suportada em algoritmos  
avanzados de Detecção Remota**

**Catarina de Fátima Vieira Marques**

Dissertação orientada pelo Professor Doutor Fernando Jorge Pedro da Silva Pinto  
da Rocha e pelo Professor Doutor César Dinis Santos Capinha

Mestrado em Sistemas de Informação Geográfica e Modelação Territorial  
Aplicados ao Ordenamento

2021





**Extração automática de áreas de recauchutagem suportada em algoritmos  
avanzados de Detecção Remota**

**Catarina de Fátima Vieira Marques**

Dissertação orientada pelo Professor Doutor Fernando Jorge Pedro da Silva Pinto da  
Rocha e pelo Professor Doutor César Dinis Santos Capinha

Júri:

Presidente: Professor Doutor António Manuel Saraiva Lopes do Instituto de Geografia e  
Ordenamento do Território da Universidade de Lisboa

Vogais:

- Professor Doutor José António Pereira Tenedório da Faculdade de Ciências Sociais e  
Humanas da Universidade Nova de Lisboa
- Professora Doutora Patrícia Catarina dos Reis Macedo Abrantes do Instituto de  
Geografia e Ordenamento do Território da Universidade de Lisboa
- Professor Doutor Fernando Jorge Pedro da Silva Pinto da Rocha do Instituto de  
Geografia e Ordenamento do Território da Universidade de Lisboa





Esta dissertação de mestrado está enquadrada nos projetos TRIAD (*health Risk and social vulnerability to Arboviral Diseases in mainland Portugal*) - Vulnerabilidade Social e Risco para a Saúde devido às doenças arbovirais em Portugal continental (PTDC/GES-OUT/30210/2017) e WARDEN (*An operational early WARning system for DENgue and other arboviral diseases in Madeira Island*) - Um modelo operacional de alerta precoce para o dengue e outras arboviroses na Ilha da Madeira (PTDC/SAU-PUB/30089/2017).



## Resumo

Existem diversos trabalhos que comparam o método de classificação baseada em *pixels* com o método de classificação orientada ao objeto que consideram melhores resultados neste último, quando associado aos métodos *pixel-a-pixel*, sendo esta uma importante ferramenta para a classificação e estudos eficientes do uso do solo (Antunes, 2003).

Os objetos nas imagens são representações reais do terreno e citando Antunes, “Desta maneira, o contexto espacial é descrito em termos de relações topológicas entre os objetos”, ou seja, relações entre as diferentes propriedades de estudo relativamente à sua disposição assim como dos diferentes elementos de um conjunto. Assim considera-se que os objetos homogêneos são representados não apenas pela sua assinatura espectral, mas também pela sua textura, e que a segmentação da imagem em diferentes escalas pode levar à criação de uma rede hierárquica relacionando objetos maior a objetos menores. A Detecção Remota desempenha um papel importante no estudo da biosfera, permitindo realizar medições em diferentes escalas e explorar os dados existentes de modo a melhorar e completar a informação, permitindo uma análise da extensão e localização das áreas urbanas e da distribuição espacial dos diferentes tipos de uso e cobertura do solo.

Nesta dissertação foi utilizada a classificação orientada ao objeto que, ao invés da classificação dos *pixels* de forma individual quanto às suas características espectrais, interpreta a informação dos objetos originados pelo processo de segmentação da imagem, dividindo esta em segmentos homogêneos, que pode ter como base a sua resposta espectral média, a variância, as dimensões, a forma, e a textura, permitindo a aquisição de informação mais precisa e detalhada (Kux, 2009).

O motivo da escolha deste tipo de classificador deve-se ao fato de os objetos de estudo não resultarem de uma resposta espectral clara, sendo representados mais facilmente pela sua forma ao invés do valor do *pixel* que se confunde com outras classes. Com esta dissertação pretende-se contribuir para o estudo de identificação de pneus ao ar livre através de métodos automáticos, tendo como base a classificação de imagem orientada ao objeto, utilizando

fotografias aéreas de alta resolução, com o intuito de ajudar a preservar o meio ambiente e a saúde pública.

**Palavras-chave:** Detecção Remota, classificação de imagem, segmentação, pneumas.

## Abstract

There are several studies that compare the pixel-based classification method with the object-oriented classification method that consider better results in the last one, when associated with pixel-by-pixel methods, which is an important tool for the classification and efficient studies of use soil (Antunes, 2003).

The objects in the images are real representations of the field and quoting Antunes, “In this way, the spatial context is described in terms of topological relationships between the objects”, that is, relationships between the different study properties in relation to their disposition as well as the different elements of a set. There for it considered that homogeneous objects represented not only by their spectral signature, but also by their texture, and that the segmentation of the image at different scales can lead to the creation of a hierarchical network relating larger objects to smaller objects. Remote Sensing plays an important role in the study of the biosphere, allowing measurements at different scales and exploring existing data in order to improve and complete the information and allows an analysis of the extent and location of urban areas and the spatial distribution of different types of land use and cover.

In this dissertation, object-oriented classification was used, which, instead of classifying pixels individually in terms of their spectral characteristics, interprets the information of objects originated by the image segmentation process, dividing it into homogeneous segments, which can be based on its average spectral response, variance, dimensions, shape, and texture, allowing the acquisition of more accurate and detailed information (Kux, 2009).

The reason for choosing this type of classifier is that the objects of study do not result *from* a clear spectral response, easily represented by their shape instead of the pixel value that is confused with other classes. This dissertation intends to contribute to the study of tire identification in the open-air using automatic methods, based on object-oriented image classification, using high-resolution aerial photographs in order to help preserve the environment and public health.

**Keywords:** Remote Sensing, image classification, segmentation, tires.



## Índice

Resumo.....	i
Abstract .....	iii
Índice de Figuras.....	vii
Índice de Tabelas.....	ix
1. Introdução.....	1
1.1. Enquadramento Geral.....	1
1.2. Objetivos .....	3
1.3. Organização do trabalho .....	5
2. Estado da Arte .....	7
3. Conceitos Teóricos .....	11
3.1. Detecção Remota.....	11
3.1.1. Radiação Eletromagnética.....	11
3.1.2. Interação da REM com a superfície terrestre.....	13
3.2. Ortofotomapas .....	16
3.2.1. Índices.....	18
3.3. Classificação de Imagem .....	19
3.3.1. Classificação supervisionada .....	20
3.3.2. Classificação não supervisionada .....	21
3.3.3. Classificação de imagem <i>pixel-a-pixel</i> .....	22
3.3.4. Segmentação da imagem orientada ao objeto .....	22
4. Metodologia .....	27
4.1. Área de Estudo .....	27
4.2. Material e <i>Software</i> .....	29
4.2.1. Direção Geral do Território .....	29
4.2.2. ESRI .....	30
4.2.3. IDRISI .....	30
4.3. Cálculo de Índices.....	30
4.4. Classificação da Máxima Verosimilhança.....	31
5. Resultados e discussão .....	42
6. Conclusão .....	47
7. Referências Bibliográficas.....	49
8. Anexos .....	54





## Índice de Figuras

Figura 1 - Distribuição de Aedes Albopictus na Europa em abril de 2017 (SNS, n.d.).	2
Figura 2 – Reprodução de mosquitos dentro de pneus ao ar livre (InterPLAST, 2020).	2
Figura 3 - Radiação eletromagnética por James Maxwell (“Radiação Eletromagnética,” 2020).	12
Figura 4 - Espectro eletromagnético e principais divisões (Biziak, 2017).	13
Figura 5 - Processos de detecção remota (Martins, 2015).	14
Figura 6 - Interações da REM na superfície terrestre (Franklin, n.d.).	15
Figura 7 - Composição RGB de imagem aérea (“Image Bands”, 2019).	17
Figura 8 - Enquadramento geográfico da área de estudo – Sines, Portugal.	27
Figura 9 - Ortofotomapa da área de estudo – Sines, Portugal.	28
Figura 10 - Áreas de treino do ArcMap.	32
Figura 11 - Resultados obtidos do MLC.	34
Figura 12 – Primeira componente principal dos três índices (água e vegetação).	35
Figura 13 - Resultados das segmentações 1, 2, 3 e 4 de acordo com a Tabela 7.	37
Figura 14 - Áreas de treino da segmentação 3.	40
Figura 15 - Áreas de treino da segmentação 5.	41
Figura 16 - Classificação resultante da segmentação 3.	42
Figura 17 - Classificação resultante da segmentação 5.	43
Figura 18 - Classificação resultante da segmentação 8.	44



## Índice de Tabelas

Tabela 1 - Dados e Softwares utilizados. ....	29
Tabela 2 - Índices aplicados em estudo de B. Quinlan et al., (2006). ....	31
Tabela 3 - Índices de vegetação e de água.....	31
Tabela 4 - Classes de área de treino no ArcMap.....	31
Tabela 5 - Valores de pixels máximo e mínimo (classe de pneus). ....	33
Tabela 6 - Condições para índices calculados. ....	33
Tabela 7 - Parâmetros de segmentação no IDRISI Selva. ....	36
Tabela 8 - Classes de área de treino. ....	38
Tabela 9 – Parâmetros de segmentação no IDRISI Selva. ....	39
Tabela 10 – Resultados da Matriz de Confusão de 3 segmentações.....	45



# 1. Introdução

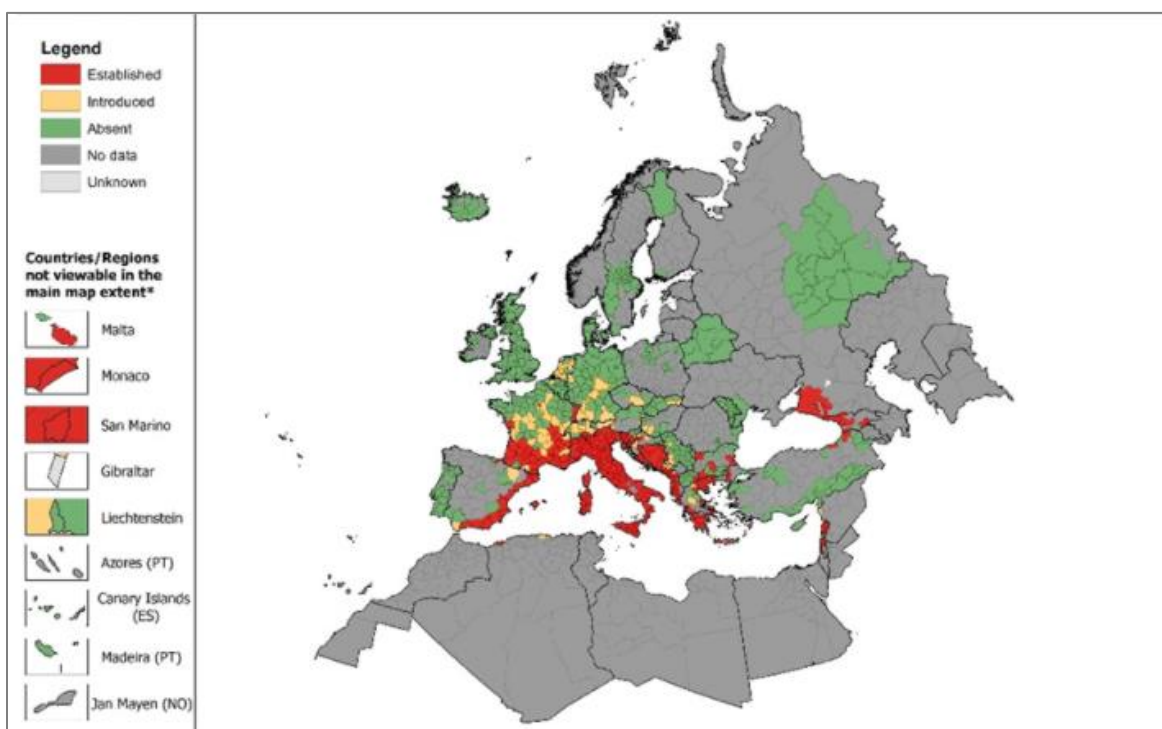
## 1.1. Enquadramento Geral

Em diversos casos a presença de pneus, que permite a acumulação de água longe da luz solar direta, foi associada em surtos de mosquitos vetores de doenças. O mosquito é um vetor de doença não só para os humanos, mas também para os animais sendo de grande interesse para a saúde pública o controlo de pragas desta natureza, estando registadas como principais doenças a malária, o dengue, o vírus do Nilo, entre outras.

Em 2005 foi registada pela primeira vez na Região Autónoma da Madeira a espécie *Aedes Aegypti* sendo atualmente um tema investigado pela REVIVE (Rede de Vigilância de Vetores), que opera em Portugal desde 2008 sobre a responsabilidade do Ministério da Saúde Portuguesa, responsável pela vigilância a nível nacional da maioria dos artrópodes hematófagos (que se alimentam de sangue) significativos para saúde pública, tais como mosquitos e carraças (Osório et al., 2018).

Em setembro de 2017, foi detetado pela primeira vez numa empresa de pneus no Norte de Portugal, no concelho de Penafiel, o mosquito tigre asiático *Aedes Albopictus* (de acordo com Skuse em 1984). Esta situação já era de certa forma expectável face à proliferação da espécie por toda a Europa Continental (Figura 1).

Como já referido ambos se enquadram no âmbito das espécies invasoras de grande preocupação para a saúde pública devido ao seu papel na transmissão de vários arbovírus tais como o dengue, a chikungunya e o zika (transmitidos por picada dos mosquitos *Aedes*). A sua propagação ocorre maioritariamente devido ao aumento de comércio e importação humana, onde os ovos são transportados em pneus usados e plantas ornamentais (Osório et al., 2018).



*Figura 1 - Distribuição de Aedes Albopictus na Europa em abril de 2017 (SNS, n.d.).*

A sua reprodução (Figura 2) acontece desde que os mosquitos colocam os seus ovos nas paredes de borracha dos pneus dando-se a sua eclosão num curto espaço de dias até se tornarem adultos (InterPLAST, 2020).



*Figura 2 – Reprodução de mosquitos dentro de pneus ao ar livre (InterPLAST, 2020).*

A recauchutagem de pneus consiste em reaproveitar a estrutura de pneus gastos, aplicando uma nova camada de borracha, por forma a poderem ser reutilizados. Esta atividade existe em Portugal há aproximadamente 70 anos, com recursos comerciais e logísticos bem definidos, e anualmente são recauchutados cerca de 342,800 unidades (valorpneu, 2020).

O armazenamento de pneus varia de acordo com a legislação local, e o depósito de resíduos de pneus usados está legislado de acordo com a Agência Portuguesa do Ambiente, a qual estabelece os princípios e normas a aplicar na sua gestão. Quanto aos novos pneus, estes são da competência do próprio fabricante relativamente à sua recolha, transporte e destino final, passando para uma entidade gestora licenciada ou com autorização para a sua gestão (Agência Portuguesa do Ambiente (APA), 2020).

Nesta dissertação têm interesse as áreas de recauchutagem ao ar livre, sendo estas da competência da Valor Pneu (VP), de acordo com o Despacho conjunto n.º 4948/2008, de 5 de fevereiro, e através do Despacho n.º 31203/2008, de 11 de novembro, para o controlo e administração de pneus usados, através de um sistema integrado (valorpneu, 2020).

Portugal tem uma população estimada de 10,25 milhões (Contemporâneo, 2020) e uma área de 92,291 km<sup>2</sup> dos quais 91,951 km<sup>2</sup> correspondem ao território continental e 440 km<sup>2</sup> à zona marítima (Pacievitch, 2020). No estudo proposto a área de estudo não é geograficamente relevante pois apenas seria necessário que existissem áreas com concentração de pneus ao ar livre e que se encontrassem visíveis nas fotografias aéreas utilizadas. Desta forma e com recurso ao serviço de pesquisa do Google Maps foi encontrada uma área na zona de Sines, distrito de Setúbal, junto à zona costeira, mais propriamente o Parque Industrial de Sines, a empresa Recipneu, sendo esta uma empresa nacional de reciclagem de pneus.

## 1.2. Objetivos

Com esta dissertação pretende-se refletir sobre a utilização de classificadores supervisionados de imagem, através de métodos de Detecção Remota (DR), particularmente no que diz respeito ao uso de fotografias aéreas de alta resolução, propondo desenvolver uma metodologia que possa ser aplicada a outras áreas de estudo por forma a reduzir custos e tempo de análise.

Apesar das imagens de baixa e média resolução se terem vindo a mostrar uma vantagem em termos de custos e serem uma fonte de dados de fácil acesso, sendo na maioria das vezes gratuita, em muitos casos tem-se verificado não serem adequadas para determinados estudos, devido aos limites impostos pela sua resolução (principalmente espacial).

O desenvolvimento de novas tecnologias permitiu o avanço dos estudos na área de DR através de métodos automáticos e semiautomáticos, com recurso a *softwares* de classificação de imagem, proporcionando o desenvolvimento de novos métodos de análise de imagens de alta resolução por meios computacionais (Leckie et al., 2003).

Ao longo dos anos desenvolveram-se técnicas de interpretação de imagens que operam no domínio de duas dimensões, e outras que conjugam a informação de várias fotografias a nível tridimensional, contribuindo para um grande número de processamentos que podem ser efetuados nas mesmas (Korpela, 2004).

Para o objetivo de monitorização de áreas de recauchutagem ao ar livre, onde estas não ocupam grandes extensões de território, é necessário o uso de imagens de alta resolução. Assim, as fotografias aéreas são também ótimas fontes de dados para estes estudos (Gomes & Maillard, 2016).

Como objetivos desta dissertação pretende-se avaliar o estado de arte e o potencial do uso de fotografias aéreas de alta resolução para identificar áreas de recauchutagem, através do teste de algoritmos já existentes, e tentar construir um método de classificação automática para áreas de recauchutagem de modo a poder ser utilizado em diferentes áreas, identificando oportunidades futuras para o mapeamento de áreas de depósitos ilegais de pneus, levando a uma monitorização com baixo custo-benefício.

O método de classificação de imagem pela segmentação tem surgido como uma alternativa aos tradicionais métodos de classificação ao nível do *pixel*, e com isto propõe-se conjugar o estudo destes dois métodos de classificação de imagens (Antunes, 2003).



### 1.3. Organização do trabalho

Esta dissertação encontra-se dividida em seis capítulos. O primeiro capítulo consiste numa introdução sobre o enquadramento geral e os objetivos propostos nesta dissertação. No segundo capítulo é feita uma apresentação do estado de arte relativamente a trabalhos elaborados para a deteção de pneus em Deteção Remota. No terceiro é feita uma apresentação teórica dos temas utilizados ao longo da dissertação. No quarto capítulo são explicados os processos metodológicos aplicados, onde primeiro foi realizada uma análise espectral no *software* ArcGIS versão 10.6.1 aplicando o algoritmo *Maximum Likelihood Classification*. Foram calculados índices testados em outros estudos para realçar os pneus, assim com o índice de vegetação e o índice de água. Posteriormente foram aplicados estes índices no processo de segmentação orientada ao objeto no *software* IDRISI versão Selva, utilizando o classificador que avalia a semelhança dos segmentos de acordo com a sua similaridade. No quinto capítulo são apresentados os resultados obtidos e a sua discussão. No sexto capítulo são tiradas as conclusões finais do estudo realizado.



## 2. Estado da Arte

Neste capítulo propõe-se apresentar os conceitos e estado de arte dos principais documentos encontrados sobre os métodos aplicados nesta dissertação relativos à deteção automática de áreas de recauchutagem.

A acumulação de pneus e materiais plásticos foram identificados como uma ameaça para a saúde humana, animal e ambiental, levando à contaminação da água e consequentemente do gado, tornando-se um ótimo combustível para incêndios e propagação de uma variedade de vetores de doenças. Para a sua identificação normalmente é necessário uma série de etapas e recursos muitas vezes dispendiosos e que ocupam muito tempo tais como equipas que efetuam levantamentos no campo ou investigação em gabinete (Quinlan, 2016).

Devido à resposta espectral dos pneus ser semelhante a outras classes de uso e ocupação do solo tais como a água e a sombra, a sua investigação ao nível da Deteção Remota tem sido menos explorada que outras classes como o caso da vegetação. As técnicas de DR ainda apontam muitos falsos positivos no uso de algoritmos para a deteção de áreas de pneus.

Dos trabalhos desenvolvidos nesta área, muitos operam com imagens de satélite tais como as do projeto Copernicus, o Sentinel-1 e Sentinel-2, conjugadas com algoritmos de classificação de imagem e *softwares* adequados (Page et al., 2020).

A aplicabilidade de fotografias aéreas na área de DR data de 1974 onde Garofalo & Wobber sugeriram a utilidade de fotografias aéreas para o planeamento e controlo de resíduos sólidos. A metodologia era baseada na interpretação visual da superfície terrestre, da sua cobertura, e a posterior introdução desses dados em modelos de produção de resíduos. Os autores sugerem que a utilização desta metodologia pode ajudar a prevenir potenciais impactos ambientais.

Salleh & Tsudagawa (2002) utilizaram um método de classificação automático em dados de câmaras de vídeo obtidos a uma altitude de 300m. Através do método de classificação de máxima verosimilhança obtiveram uma exatidão de cerca de 97% após aplicarem um filtro

espacial, tendo-se no entanto mostrado um método pouco explícito e, portanto, difícil de replicar.

David Eaton (2007) tentou identificar o valor espectral da classe de pneus e de classes que apresentassem características espectrais semelhantes. No *software* ERDAS criou uma classificação preliminar. De seguida fez sobressair a classe de pneus relativamente às restantes, alterando a sua cor, tentando desta forma isolar esta classe das restantes que apresentam respostas espectrais semelhantes. Nas classificações seguintes, a água e a sombra apresentaram-se como falsos positivos. O autor conclui que a identificação de pilhas de pneus isolados não é um método fácil de ser aplicado devido à sua semelhança espectral com outras classes e também à sua distribuição geográfica. O número de falsos positivos poderia facilmente ser eliminado pelo método *eyeballing*, contudo este pode ser demorado e incorreto sendo necessária uma verificação no terreno.

De acordo com Glanville & Chang (2015) que realizaram estudos onde foram utilizadas fotografias aéreas à escala 1:10000, não tem sido feita uma adequação apropriada do seu uso para o mapeamento de resíduos de pneus desde o ano 2000 até à data do seu artigo.

Na Califórnia foi realizado um estudo com imagens de satélite de alta resolução para detetar automaticamente locais de depósito de pneus usados assim como áreas ilegais para a reciclagem destes (possíveis locais de incêndios e risco de vetor de doença - acumulação de água para habitats de mosquitos).

Quinlan (2016) utilizou técnicas automáticas e manuais de processamento de imagem. O autor afirma que existe pouca pesquisa sobre o mapeamento de áreas de pneus reciclados, utilizando métodos de deteção automáticos. Refere ainda que Beavers (1996) identificou pilhas de pneus em Kentucky, Indiana e Ohio através da utilização de vídeo-fotografia aérea de baixa altitude, em dias pouco nublados (evitando as sombras) com uma resolução de 0,5 metros, através da medição de assinaturas espectrais, não encontrando diferenças significativas. Apenas encontrou diferenças espectrais entre pneus limpos e pneus cobertos. O seu estudo provou que é difícil distinguir áreas de pneus, zonas escuras (e.g., sombras) e água.

Quinlan utilizou um modelo de identificação de pneus a partir de dados de refletância (TIRe) separadamente, tendo depois processado todas as imagens, originando um mosaico para produção de mapa final utilizando o *software* ERDAS *Imagine Model Builder* da Leica Geosystems, para criar um modelo automático para isolar pneus em todas as regiões climáticas. Os valores digitais dos pneus variaram de imagem para imagem tendo sido testadas várias combinações de bandas espectrais para isolar pneus. Através de um algoritmo do *software* e algumas modificações, conseguiu eliminar toda a vegetação significativa e algumas características de água escura. Utilizou também a função HUE para eliminar os *pixels* que não seriam de pneus nas imagens originais, assim como áreas de solos escuros e algumas de água. Teve um sucesso de eliminação/limpeza entre 83% e 99% em cada imagem.

No trabalho de Page et al. (2020) o objetivo consistia em desenvolver um método de classificação de imagem preciso para detetar pneus e plásticos, e criar uma plataforma que permitisse o seu uso em grandes extensões e de forma repetitiva utilizando imagens de satélite Sentinel-1 e 2 do ano 2018 para a região de Glasgow e Edimburgo na Escócia, por forma a avaliar o método de classificação *Random Forest* (RF). Testou vários índices tais como o NDVI, SAVI e  $NDWI_2$  entre outros. Testou 2 métodos de classificação RF tendo obtido sucesso na deteção de pneus com uma exatidão média de 85%. O seu método mostrou ser confiável tendo aplicado a mesma metodologia em imagens Worldview-2, que apresentaram melhores resultados.

Estes trabalhos mostraram que com a aplicação de algoritmos em deteção remota, é possível criar metodologias para a deteção rápida e eficiente de pneus ao livre.



### 3. Conceitos Teóricos

#### 3.1. Detecção Remota


A Detecção Remota (DR) é definida como uma ciência que permite a aquisição de informação de um objeto ou fenómeno, através de imagens da superfície terrestre. Estas imagens são normalmente adquiridas por meios aéreos, tais como sensores a bordo de satélites artificiais ou câmaras instaladas em aeronaves, nos quais não existe contato físico com os objetos. Os dados são adquiridos remotamente e são analisados por meios computacionais, permitindo descrever as características dos objetos ou fenómenos em estudo.

A DR engloba três processos básicos, o de aquisição, o de análise e processamento de dados através de dispositivos de visualização, e a interpretação. No geral resume-se ao registo de variações de reflexão e emissão de energia eletromagnética à superfície da Terra, sendo que a atmosfera pode ter um impacto profundo na composição espectral e radiação dos objetos (Lillesand & Kiefer, 1979).

##### 3.1.1. Radiação Eletromagnética

A radiação eletromagnética (REM) proveniente do Sol permite conhecer as propriedades físicas e químicas dos objetos nos quais incide, através da energia refletida por esses mesmos objetos. Esta radiação que se propaga através do espaço sem necessidade de suportes físicos, em conjunto com a radiação dos próprios objetos e as próprias variações espectrais devido à temperatura terrestre, permite uma melhor interpretação dos objetos em estudo.

De acordo com James Maxwell, a REM (Figura 3) consiste na propagação de um campo magnético e de um campo elétrico, orientados ortogonalmente entre si, formando uma onda (movimento ondulatório) que avança na direção perpendicular ao plano que contém os dois vetores. (Fonseca & Fernandes, 2004).



**Figura 3 - Radiação eletromagnética por James Maxwell ("Radiação Eletromagnética," 2020).**

Já Max Planck propôs o efeito fotoelétrico que explica que a REM é composta por partículas designadas de fótons. De acordo com a sua teoria quântica, quando os elétrons transitam de órbitas de menor nível energético, onde a energia excedente é fornecida aos fótons, é produzida a REM, sendo a energia dos fótons ( $Q$ ) e a frequência da onda de propagação ( $f$ ) proporcionais,


$$Q = hf, \quad (1)$$

onde  $h = 6.626 * 10^{-34} Js$  (Joules por segundo), sendo esta constante  $h$  designada de constante de Planck.

A transferência de energia que ocorre entre os fótons e os átomos dos objetos tem como consequência a alteração da energia eletromagnética quando interage com esses objetos.

A energia eletromagnética encontra-se em diferentes formas, normalmente caracterizada pela localização de comprimentos de onda no espectro eletromagnético (Figura 4), sendo que em DR as energias mais utilizadas são a luz visível (que abrange uma pequena parte do espectro, visto a sensibilidade espectral do olho humano se encontrar entre os valores de 0,4 e 0,7  $\mu m$ ), infravermelho próximo, médio ou térmico (que se encontra entre os valores de 0,7 e 3  $\mu m$ ) e micro-ondas (que se encontra entre os valores de 1mm e 1m). Quanto maior for o comprimento de onda, menor será a quantidade de energia (Fonseca & Fernandes, 2004).






**Figura 4 - Espectro eletromagnético e principais divisões (Biziak, 2017).**

### 3.1.2. Interação da REM com a superfície terrestre

Em DR existem dois tipos de sistemas, os sistemas passivos que permitem detetar a REM refletida ou emitida pela superfície terrestre (Figura 5), onde as principais fontes de energia são o Sol e a superfície terrestre (emissão), e os sistemas ativos que produzem sinal através de um emissor não natural, iluminando o alvo através de dispositivos de micro-ondas designadas de RADAR (*RADio Detetion And Ranging*).

Qualquer corpo emite REM desde que a sua temperatura esteja acima do zero absoluto, podendo ser gerada por transformações de outras formas de energia tais como a energia nuclear, térmica, elétrica entre outras (Fonseca & Fernandes, 2004). A energia total emitida por um objeto pode variar de acordo com a sua temperatura, variando também a distribuição espectral da energia emitida. A quantidade de energia emitida/refletida nas diferentes bandas do espectro eletromagnético também varia de acordo com o tipo de objeto (Lillesand & Kiefer, 1979).



**Figura 5 - Processos de detecção remota (Martins, 2015).**


Quando a REM incide nos objetos pode ocorrer (Fonseca & Fernandes, 2004):

- a) Absorção com trocas de energia entre os átomos do objeto e os fótons, podendo desta forma aumentar a temperatura desses mesmos objetos através de transformações físicas;
- b) Reflexão onde a REM é em parte refletida para o espaço, permitindo calcular a assinatura espectral do objeto, sendo esta a que atribui cor e tom às fotografias;
- c) Transmissão onde a REM cruza o objeto sem interferir com as suas partículas, e liberta-se na parte oposta à de incidência.

Devido a estas interações, os valores de magnitude, direção e comprimento de onda fazem variar o espectro eletromagnético.

Conforme a variação de temperatura do objeto, o comprimento de onda altera, onde quanto mais quente, altera para comprimentos de onda mais curtos. Todas as interações dependem do comprimento de onda ( $\lambda$ ) da REM, do seu ângulo de incidência e o tipo de material onde incide. Esta distribuição varia de acordo com a equação do balanço energético que diz que a energia radiante incidente é igual à soma das energias radiantes absorvida, transmitida e refletida,

$$ERi = ERt + ERa + ERr \quad , \quad (2)$$



**Figura 6 - Interações da REM na superfície terrestre (Franklin, n.d.).**

Os objetos apresentam diferentes índices de reflectância de acordo com o comprimento de onda da radiação. Por exemplo, num objeto opaco face a determinado comprimento de onda a refletividade é nula, enquanto um objeto tido como um espelho esta é elevada. Assim, para uma análise da REM à superfície terrestre é necessário introduzir o parâmetro da reflectância (Fonseca & Fernandes, 2004).

O estudo por métodos de DR tem como objetivo a monitorização da superfície terrestre. Os resultados podem servir para atualização de cartografia ou utilizadas como apoio na produção cartográfica, por exemplo, o estudo do uso do solo, atividades agrícolas, entre outra (Thomas Blaschke et al., 2001).

Nos métodos de DR têm vindo a ser estudadas três grandes áreas, a vegetação, o solo, e a água, que apresentam comportamentos distintos nos vários comprimentos de onda. Existem inúmeros trabalhos realizados no âmbito destas três áreas onde é possível identificar a reflectância individual de cada uma delas. No estudo da vegetação por exemplo, a clorofila absorve fortemente energia em baixos comprimentos de onda permitindo a identificação da espécie em causa e se a planta é ou não saudável.

Já o solo reflete em bandas espectrais menos específicas podendo variar de acordo com a sua textura, humidade, rugosidade e presença de determinados minerais. Ao considerar a água, esta absorve radiação em comprimentos de onda próximo do infravermelho, e a sua

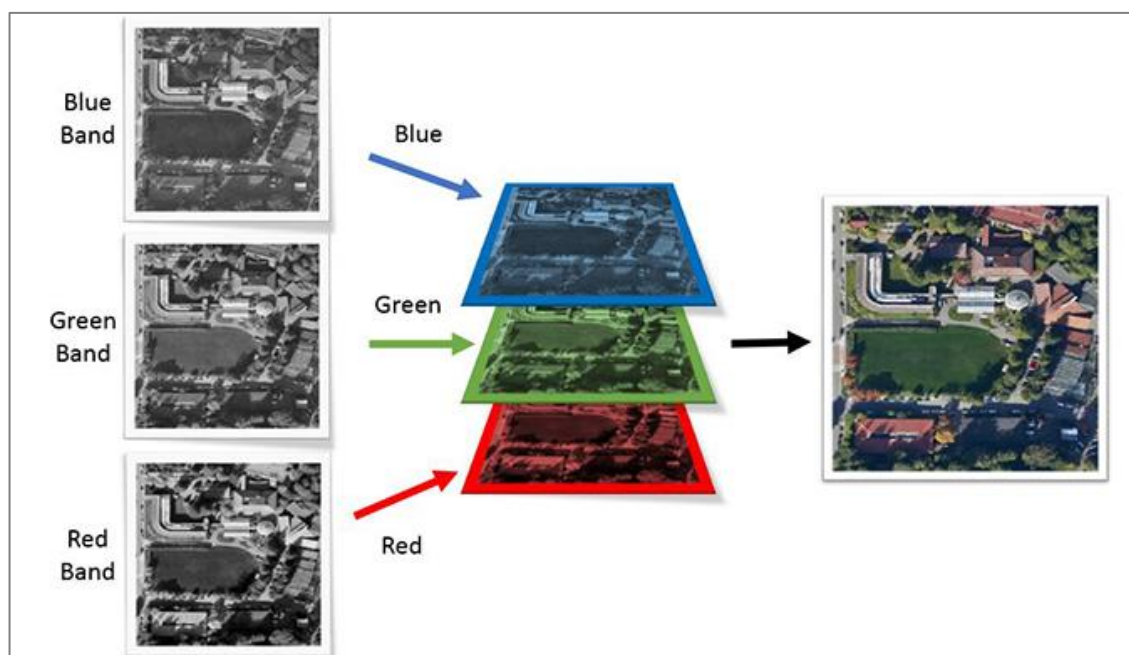
reflectância varia não só de acordo com a sua massa mas também com o material nela contida (Lillesand & Kiefer, 1979).

### 3.2. Ortofotomapas

A utilização de fotografias aéreas, principalmente as obtidas através de veículos aéreos não tripulados (VANT) apresenta vantagens em DR em alternativa às imagens de satélite, podendo ser obtidas a baixo custo e de forma mais rápida, possuindo uma resolução espacial equivalente ou por vezes até superior às imagens de satélite, assim como uma maior integridade geométrica. A sua aquisição permite obter imagens mais limpas e em áreas de difícil captação pelas imagens de satélite. Contudo, a sua interpretação visual pode exigir um treino extensivo (Chenari et al., 2017).

As fotografias aéreas podem ser adquiridas através de câmaras de grande resolução, possibilitando a recolha e análise de informação a grande escala, tornando possível a medição das características dos objetos através da captura de uma sucessão de fotografias (Miranda, 2004). Permitem assim uma análise detalhada da superfície terrestre e de muitas das suas características tendo em consideração que a escala da imagem afeta o nível de informação útil que pode ser extraída da fotografia (Lillesand & Kiefer, 1979).

Estas câmaras devem conseguir produzir imagens coloridas que controlam a quantidade de energia azul, verde e vermelha, formando uma imagem fotográfica. Estas três bandas podem ser exibidas em simultâneo ou separadamente, e com elas é possível realizar uma série de transformações de forma a melhorar a visualização da informação. Assim as imagens compostas por várias bandas designadas de ortofotomapas (Figura 7) apresentam diferentes valores relativamente ao espectro eletromagnético e cada banda exprime a energia refletida numa determinada zona desse espectro.



**Figura 7 - Composição RGB de imagem aérea (“Image Bands”, 2019).**

Nenhuma combinação é única e não pode ser aplicada a todas as análises, no entanto, de acordo com os padrões de resposta espectral de cada imagem, é possível criar combinações ideais para cada situação. Estas combinações podem também incluir bandas de infravermelho, também muito comuns nas fotografias aéreas.

Os objetos na imagem apresentam diferentes formas e tamanhos podendo uns ser facilmente identificáveis e outros não. As interpretações podem ocorrer com vários níveis de complexidade, desde o reconhecimento dos objetos à derivação da informação em detalhe sobre as suas interações. As técnicas visuais fazem uso da excelente capacidade da mente humana para avaliar qualitativamente os padrões espaciais de uma imagem, podendo exigir um treino extensivo, para além de que nem sempre é possível avaliar as características espectrais de uma imagem apenas de forma visual. O sucesso da interpretação varia de acordo com a experiência do utilizador (Lillesand & Kiefer, 1979).

No que diz respeito à interpretação visual de uma imagem, Maxwell e Planck concluem que esta é melhor aprendida através da visualização de centenas de imagens, tornando-se um processo demorado e exaustivo.

### 3.2.1. Índices

Como referido, os ortofotomapas são compostos por diferentes bandas espectrais, tendo sempre por defeito três bandas correspondentes ao vermelho, verde e azul, i.e., visível. Para além destas, poderão conter outras bandas espectrais, dependendo do tipo de sensor de captura das mesmas. Para uma melhor interpretação poderá ser necessário aplicar operações que permitam a construção de novas bandas, a partir das diferentes bandas que constituem a imagem. Estas bandas resultantes de somas, multiplicações e outras operações, representam as bandas originais num espaço de frequências (Fonseca & Fernandes, 2004).

#### 3.2.1.1. Índice de Vegetação

No caso da vegetação, na faixa do visível esta absorve radiação nos comprimentos de onda do azul e do vermelho, e reflete nos comprimentos de onda do verde. Na faixa do infravermelho reflete consoante o tipo de folhagem, permitindo estudar a vegetação saudável e não saudável.

Os índices de vegetação (IV) resultam de uma transformação aritmética entre as diferentes bandas que constituem a imagem. Estes índices traduzem os valores de biomassa, área foliar, percentagem de coberto entre outros, e permitem a correlação entre dados espectrais com parâmetros de vegetação e realçando as diferenças espectrais (Hussain, Chen, Cheng, Wei, & Stanley, 2013). Um IV deve conseguir minimizar os efeitos de variação externa provocadas pela atmosfera assim como a geometria de iluminação e observação, e deve também conseguir isolar visualmente os valores de verde e não verde como a água e o solo.

Com os IV é possível verificar a vegetação saudável (refletindo na faixa infravermelho próximo e absorvendo na faixa do visível), onde quanto mais clorofila estiver presente, mais elevado será o valor do índice.

De entre os diversos IV que existem, será referido o utilizado neste estudo, o índice NDVI (*Normalized Difference Vegetation Index*) que opera com a banda do vermelho e do infravermelho,

$$NDVI = \frac{NIR - Red}{NIR + Red} , \quad (3)$$

Este índice tem sido aplicado em estudos sobre a vegetação global, permitindo verificar e estudar as alterações a nível de cobertura da superfície terrestre (Hussain et al., 2013).

#### 3.2.1.2. Índices de Água

Existem diferentes índices de água, e para o caso de estudo foi escolhido o NDWI (*Normalized Difference Water Index*). Este permite realçar recortes na água, minimizando as restantes classes de ocupação do solo, através de imagens obtidas em DR. Este índice consegue identificar a água a partir da radiação refletida na faixa do infravermelho próximo e da luz verde visível distinguido desta forma a água e a vegetação à superfície terrestre, sendo que valores iguais ou acima de zero correspondem à presença de água, e abaixo de zero correspondem a vegetação (McFeeters, 1996).

$$NDWI = \frac{Green - NIR}{Green + NIR} , \quad (4)$$

$$NDWI_2 = \frac{Green - Red}{Green + Red} , \quad (5)$$

### 3.3. Classificação de Imagem

A classificação de imagem é feita através dos Sistemas de Informação Geográfica (SIG), aplicados em DR, que mostraram ser uma ferramenta de elevada importância no mapeamento e monitorização da superfície terrestre, com recurso a sensores em satélites e também veículos aéreos que permitem a aquisição de imagem a baixa, média e alta resolução com custos consideravelmente reduzidos (Ke & Quackenbush, 2011).

Para além da interpretação visual, existem vários métodos de análise em DR tais como a classificação de imagem por meio de algoritmos computacionais que permitem uma análise de padrões espaciais, espectrais e temporais, consistindo assim numa técnica de processamento digital, que tem sido muito utilizada em estudos de uso e ocupação do solo.

O processo de classificação pode ser totalmente visual requerendo muito tempo de execução, e um cuidado rigoroso com a padronização e uniformização dos critérios. Deste modo, os métodos de classificação automática ou semiautomática ganham relevância. Os classificadores automáticos podem ser supervisionados ou não supervisionados, *pixel-a-pixel* ou contextuais.

Para cada caso de estudo é necessário perceber qual o melhor método a aplicar. A classificação orientada a objetos procura melhorar o desenvolvimento das técnicas de classificação automática, que detêm meios que permitem a sistematização e reprodução do conhecimento do utilizador (Kux, 2009).

### 3.3.1. Classificação supervisionada

Este tipo de classificação é utilizado para análises quantitativas dos dados, onde são delimitadas áreas de interesse nas imagens em estudo, denominadas de áreas de treino. Este tipo de análise realizada a nível computacional, através de algoritmos adequados permite analisar a resposta espectral das diferentes classes de ocupação do solo, verificando desta forma a semelhança das assinaturas espectrais. As áreas de treino podem e devem ser ajustadas sempre que necessário, de modo a melhorar os resultados obtidos.

Esta classificação consiste em agrupar automaticamente todos os *pixels* de uma imagem em classes com base na relação espacial dos *pixels* em redor. Este processo ocorre pela aplicação de algoritmos, onde é necessário criar uma área de treino para cada classe, e de acordo com os seus atributos espectrais, é possível classificar de forma automática toda a imagem (Lillesand & Kiefer, 1979).

Surgem duas etapas, a primeira de treino e a segunda de classificação. Se um *pixel* não se enquadra em nenhuma área de treino, é categorizado como desconhecido. No final da classificação podem resultar por exemplo, mapas ou tabelas que podem ser utilizados em SIG. Durante a fase de treino, os padrões espectrais, em conjunto com os dados da imagem, são avaliados no computador através dos algoritmos já existentes, que permitem a identificação



individual de cada *pixel*. A qualidade do processo de criar áreas de treino determina o sucesso da classificação.

Para um melhor resultado as áreas de treino devem ser as mais representativas e completas possíveis ao longo de cada imagem. Determinadas classes podem se dividir em subclasses, não existindo um limite de classes de treino. Quantos mais *pixels* forem usados nas áreas de treino, melhor será a representação de cada classe, e, para uma mesma classe é importante ter diferentes locais ao longo da imagem. Podem e devem ser realizados vários testes para alcançar o resultado desejado (Lillesand & Kiefer, 1979).

Dentro dos métodos que permitem este tipo de classificação será mencionado o método da probabilidade de máxima verosimilhança que será descrito no ponto seguinte (Richards & Jia, 2006).

#### 3.3.1.1. Método de classificação pela probabilidade de máxima verosimilhança

Este método também conhecido como *Maximum Likelihood Classification* (MLC), consiste num modelo que utiliza a média e a variância das assinaturas espectrais de cada classe, através de um modelo estatístico, estimando assim a probabilidade de pertencerem a uma determinada classe espectral. Este classificador necessita de dados de treino criados pelo utilizador, pressupondo que os *pixels* de uma determinada classe apresentam uma distribuição normal (Crósta, 1992).

#### 3.3.2. Classificação não supervisionada

Esta classificação não necessita que o utilizador tenha conhecimento prévio das classes que serão classificadas, sendo utilizada uma análise de aglomeração de dados ou *clustering* que consiste no agrupamento de *pixels* num espaço multiespectral onde os *pixels* de um mesmo grupo apresentam características espectrais semelhantes através de medidas de distâncias tais como a distância euclidiana. Esta análise permite classificar os *pixels* e determinar a localização e número de classes. Feito isto o utilizador atribuirá *à posteriori* um nome a cada uma das classes (Richards & Jia, 2006).

### 3.3.3. Classificação de imagem *pixel-a-pixel*

Na década de 1970 foram desenvolvidos conceitos básicos sobre o processamento e métodos de classificação de imagens *pixel-a-pixel* utilizados nos dias de hoje, e ao longo dos anos a informação obtida por DR tem vindo a apresentar um aumento de resolução espacial e uma maior disponibilização de dados ao público (Thomas Blaschke et al., 2001).

Estes modelos tradicionais de classificação de imagens recorrem à análise de valores de *pixels* nas respetivas bandas espectrais que constituem essas imagens. Esta classificação visa identificar a classe a que cada *pixel* pertence. Contudo, este torna-se um processo limitado a uma análise pontual que se baseia somente em atributos espectrais (Congalto & Green, 1999).

Existem algumas limitações no uso desta análise tais como a perda de informação relativamente à informação dos *pixels* em redor, classes heterogéneas podem obter uma má classificação, e até mesmo a presença de *pixels* mistos.

Esta classificação é feita através dos SIG aplicados em DR, que mostraram ser uma ferramenta de elevada importância no mapeamento e monitorização da superfície terrestre, com recurso a sensores em satélites e também veículos aéreos que permitem a aquisição de imagem a baixa, média e alta resolução com custos consideravelmente reduzidos (Ke & Quackenbush, 2011).

Durante a análise espectral, pode ocorrer que algumas classes como por exemplo edifícios, estradas, estacionamento e outras, apresentem similaridade nas suas respostas espectrais devido à composição material de cada objeto ou até mesmo *pixels* com multi-representação nos seus valores. Desta forma a classificação de imagens apenas em análise espectral pode resultar em classificações menos corretas.

### 3.3.4. Segmentação da imagem orientada ao objeto

A necessidade de análise para além da referida no ponto anterior faz com que os métodos de processamento de dados em DR estejam em constante desenvolvimento, nomeadamente

devido às elevadas resoluções espaciais das imagens obtidas, que exigem tipos diferentes de processamento (Blaschke & Kux, 2005).

Com isto, tem-se considerado a análise da imagem ao nível do objeto, relacionando-a com as suas características espectrais, considerando assim não só o valor do *pixel*, mas também as características físicas que esses objetos apresentam na imagem, tais como a sua dimensão, forma e textura.

Esta classificação apresenta novas vantagens onde são consideradas regiões de *pixels* ao invés de valores isolados, maior número de variáveis a considerar no processamento de classificação utilizando as características da forma do objeto, textura e relações entre os objetos vizinhos (Hay & Castilla, 2008).

A segmentação de imagem consiste em dividir uma imagem em pequenos grupos de objetos de acordo com o seu grau de homogeneidade, por forma a classificar o elemento no terreno. Estes representam os objetos reais na superfície terrestre (Antunes, 2003), originando várias regiões que não se sobrepõem (López, 2012). Existem vários métodos de segmentação baseados em diferentes fatores de entrada tais como atributo, textura, ou resposta espectral, sendo os mais utilizados os que se baseiam na descontinuidade e similaridade.

Para o caso de estudo foi utilizada a segmentação orientada ao objeto. A segmentação em objetos homogêneos, de acordo com a homogeneidade espectral ou da forma do objeto, parte de um elemento e analisa os seus vizinhos para agrupar ou não na mesma classe. Para isto acontecer é calculado um grau de adequabilidade ou homogeneidade (GH) cujo patamar de decisão designado por Escala, determina a dimensão dos objetos criados (Fonseca & Fernandes, 2004). Esta segmentação deve ser o mais uniforme e homogênea possível.

Posteriormente, os segmentos são agrupados de acordo com determinados critérios sempre baseados na homogeneidade. A alteração de parâmetros permite ajustar o agrupamento de segmentos por forma a obter o resultado mais homogêneo possível (Molenaar, 1998).

Não existe um modelo geral de segmentação sendo este um processo empírico e de modo geral adaptável aos diferentes tipos de imagem. A segmentação de imagem baseia-se em algoritmos que relacionam as propriedades básicas de valores de níveis de cinzento, que dividem a imagem (Tilton, Marchisio, Koperski, & Datcu, 2002). Existem diferentes algoritmos de segmentação:

- a) Segmentação baseada em limites (*edge-based*) – análise em termos de cor e textura, dependentes dos limites encontrados na imagem, marcando a localização de descontinuidades; poderá ser necessário um conhecimento primário de forma a construir resultados mais fiáveis;
- b) Segmentação baseada em regiões (*region-based*) – verifica os elementos na imagem e constrói regiões de acordo com a sua similaridade, podendo dividir-se em crescimento de regiões onde parte de pontos iniciais até criar regiões homogéneas, ou divisão/junção de regiões onde as regiões iniciais são arbitrárias e posteriormente unidas ou divididas até perfazerem as condições requeridas; neste caso não são usados pontos iniciais;
- c) Segmentação por limiares (*point-based*) – quando os objetos podem facilmente ser identificados pelo valor do *pixel*;
- d) Segmentação combinada – quando vários algoritmos são combinados como por exemplo os acima referidos.

A segmentação orientada ao objeto ocorre com dois critérios sendo eles o critério da cor que está relacionada com a homogeneidade espectral e o critério da forma que está relacionada com a homogeneidade espacial (Haralick & Shapiro, 1985).

Após ocorrer a segmentação da imagem, esta passa a vetorial, e repetindo este processo de segmentação, é possível alterar ou inserir mais parâmetros possibilitando o aumento de relações entre os diferentes níveis de escala, dando origem aos termos subobjecto, i.e., objeto se encontra num nível de segmentação com mais detalhe, e superobjeto onde o detalhe é inferior e corresponde a conjuntos de subobjectos (Willhauck, 2000).

As técnicas de processamento orientadas ao objeto podem gerar algum conflito durante o seu processo devido a duas situações: o contraste da tonalidade entre os segmentos vizinhos ser muito marcado, ocorrendo uma segmentação excessiva, ou o contraste de tonalidade ser insuficiente havendo uma subsegmentação (Thomas Blaschke et al., 2001).

Combinando os SIG com DR, é possível desenvolver um automatismo através da classificação de imagens, de forma a detetar áreas de interesse na superfície terrestre. Por si só a segmentação não costuma ser suficiente para reclassificar uma imagem.

#### 3.3.4.1. Segmentação baseada no crescimento de regiões

Como referido no ponto 3.3.4. esta segmentação parte de um conjunto de pontos, e de acordo com a resposta espectral de cada um, é confirmado o critério de homogeneidade, comparando esses pontos com os *pixels* vizinhos. Se o critério for bem estabelecido, então serão agrupados *pixels* vizinhos a esse conjunto inicial, criando uma região de *pixels*, ocorrendo este processo até que o critério de homogeneidade seja satisfeito (Ke & Quackenbush, 2011).

#### 3.3.4.2. Segmentação Multiresolução

Esta segmentação consiste numa técnica de crescimento de regiões, que se baseia na fusão, definida pela homogeneidade das características espaciais e espectrais dos objetos em estudo. Este algoritmo baseia-se em parâmetros ajustáveis tais como a cor, a forma, suavidade e compacidade. Neste caso os critérios de cor e forma são ajustados automaticamente consoante se altera um, ou outro critério. Para a homogeneidade, quanto maior for o valor dos parâmetros da forma, menor será o contributo do valor espectral do objeto. Da mesma forma os critérios de suavidade e compacidade estão relacionados e permitem suavizar os valores (Baatz & Schape, 2000).

O parâmetro da escala também deve ser tido em consideração pois afeta a dimensão média dos objetos sendo que quanto maior a escala, maiores estes serão, pois este parâmetro interfere diretamente na dimensão, forma e número de segmentos gerados (Thomas Blaschke

et al., 2001). Com este algoritmo é possível relacionar a informação espectral com forma, textura, e relações de vizinhança dos objetos (Tilton et al., 2002).

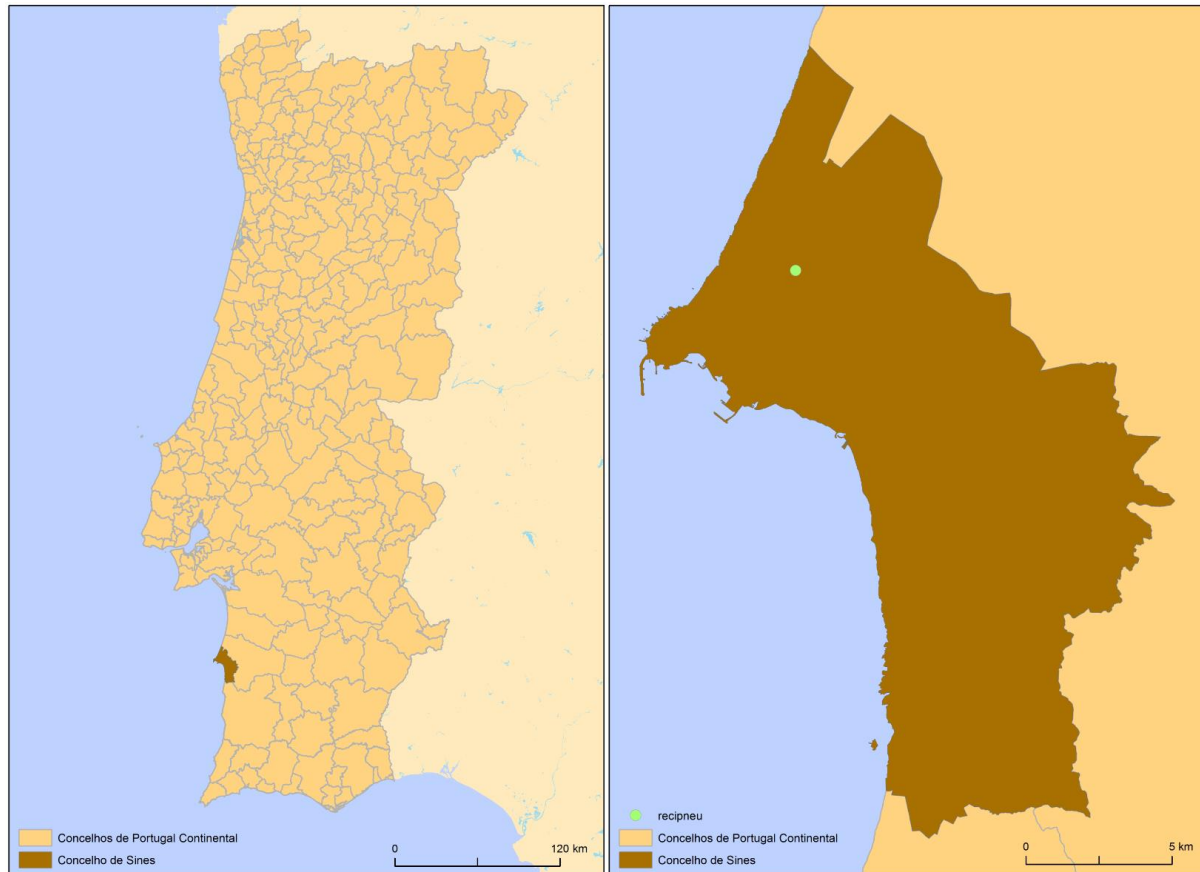
## 4. Metodologia

A classificação dos *pixels* pode provocar erros de omissão e comissão provocando uma mistura entre diferentes classes espectrais. Se conjugarmos uma classificação de imagem orientada ao objeto é possível estudar mais atributos além da informação espectral tais como a textura, a forma, análises de proximidade e também atributos temporais (Marpu, 2009).

Desta forma, primeiro foi realizada uma abordagem de classificação ao nível do *pixel*, procedendo-se posteriormente a uma classificação orientada ao objeto. Para ambos os casos foram criadas áreas de treino.

### 4.1. Área de Estudo


Na Figura 8 é possível visualizar a área de estudo enquadrada em Portugal Continental, assim como a empresa Recipneu identificada como o ponto a verde no mapa.



**Figura 8 - Enquadramento geográfico da área de estudo – Sines, Portugal.**



A área escolhida (Figura 9) encontra-se inserida num parque industrial envolvido por áreas de ocupação natural, englobando uma multiplicidade de classes de uso ocupação do solo que permitirão testar a metodologia desenvolvida.



**Figura 9 - Ortofotomapa da área de estudo – Sines, Portugal.**



## 4.2. Material e Software

Na Tabela 1 encontra-se a informação relativa aos dados e *softwares* utilizados no estudo e respetivas fontes.

**Tabela 1 - Dados e Softwares utilizados.**

Dados e Software	Fonte
Ortofotomapas à escala 1:10.000 com <i>pixel</i> de 50 cm constituídas por 4 bandas espectrais (RGB+ NIR)	DGT
Software ArcMap versão 10.6.1	ESRI
Software IDRISI versão Selva	IDRISI

O processamento dos dados foi gerado em ambiente SIG, no sistema de coordenadas *Datum 73 Hayford Gauss*.

### 4.2.1. Direção Geral do Território

A Direção Geral do Território (DGT), criada e aprovada ao abrigo do Decreto de Lei n.º 7/2012 de 17 de janeiro, é uma instituição portuguesa de prestígio, sob a alçada do Ministério do Ambiente, que fomenta o desenvolvimento territorial, sendo reconhecida a nível nacional no que diz respeito aos trabalhos desenvolvidos no âmbito da informação geográfica.

Sendo uma entidade pública com profissionalismo, competência, responsabilidade, inovação e transparência, compromete-se com a valorização da informação geográfica e do território, transição digital e abertura institucional (DGT, n.d.).

Dentro das diversas tarefas, procuram criar bases de dados geográficas de referência, nomeadamente do Sistema Nacional de Informação Geográfica de Exploração e Gestão de Informação Cadastral e manter a rede geodésica nacional assim como a produção de cartografia nacional de referência (EPortugal, n.d.).

#### 4.2.2. ESRI

Criada em 1960 e sendo pioneiros em resolver problema em SIG, a ESRI (*Environmental Systems Research Institute*) é uma empresa global que procura soluções nos sistemas de informação geográfica, que disponibiliza diversos serviços na tecnologia ArcGIS, o *software* desenvolvido pela empresa que permite análises espaciais baseadas na localização.

De entre os vários *softwares* desenvolvidos pela empresa, neste trabalho foi utilizado o ArcMap versão 10.6.1. que contém diversos recursos que permitem criar, editar e partilhar informação entre os diversos utilizadores. Contém inúmeras ferramentas de análise de dados e permite estudar as mais diversas áreas dos SIG, incluindo a Deteção Remota (ESRI, n.d.).

#### 4.2.3. IDRISI

O IDRISI, desenvolvido em 1987, é um *software* desenvolvido pelo centro de pesquisa Clark Labs da Universidade Clark, que permite o processamento de imagem no âmbito dos SIG desde a sua visualização à análise de informação espacial. O seu nome teve origem do cartógrafo e geógrafo Abu al-Idrisi da época medieval, altura em que desenvolveu material de referência por mais de 500 anos, através de investigação geográfica, sendo este o objetivo do *software* (Eastman, 2012).

À data de hoje e devido as novas atualizações que sofreu, o *software* passou a ter o nome TerrSet 2020, desenvolvido com o foco no desenvolvimento sustentável e da conservação do ambiente, oferece ferramentas mais inovadoras para o estudo das alterações climáticas e dos impactos que podem causar nos ecossistemas e na biodiversidade (Clark Labs, 2020).

### 4.3. Cálculo de Índices

De acordo com um estudo realizado por Quinlan, Huybrechts, Schmidt, & Skiles (2006), foram aplicados e testados os índices que provaram ser eficazes na identificação de *pixels* correspondentes a depósitos de pneus (Tabela 2).

**Tabela 2 - Índices aplicados em estudo de B. Quinlan et al., (2006).**

Índice 1	Índice 2	Índice 3
$res1 = Red + Green + Blue$	$res2 = \frac{NIR}{Red + Green + Blue}$	$res3 = \left(\frac{NIR}{Red}\right)^{-2}$

De modo a aumentar a discriminação espectral nas diferentes classes, foi calculado o índice NDVI, que permite determinar a existência ou ausência de áreas de vegetação na imagem em estudo. Para além deste foram ainda calculados dois índices de água, o NDWI e o  $NDWI_2$  (Tabela 3).

**Tabela 3 - Índices de vegetação e de água.**

Índice de Vegetação	Índices de Água	
$NDVI = \frac{NIR - Red}{NIR + Red}$	$NDWI = \frac{Green - NIR}{Green + NIR}$	$NDWI_2 = \frac{Green - Red}{Green + Red}$

#### 4.4. Classificação da Máxima Verosimilhança

A primeira análise foi realizada no *software* ArcMap, aplicando o algoritmo *Maximum Likelihood Classification* (MLC), onde foram criadas áreas de treino de acordo com as classes apresentadas na Tabela 4. Uma vez que existem diferentes respostas espectrais para uma mesma classe temática, em algumas delas foram consideradas subclasses.

**Tabela 4 - Classes de área de treino no ArcMap.**

Classes	Nº de classes representativas
Areia	3
Verdes	1
Depósito	3
Estrada	1
Hidrografia	6
Piscina	2
Pneus	1
Terra	1
Urbano	8



Como se pode verificar na Figura 10, as áreas de treino encontram-se bem distribuídas ao longo de toda a área de estudo.



**Figura 10 - Áreas de treino do ArcMap.**

Para cada resultado foram verificados os valores máximo e mínimo dos *pixels* da classe dos pneus (Tabela 5).

**Tabela 5 - Valores de pixels máximo e mínimo (classe de pneus).**

Índice	Nome <i>Output</i>	Valor mínimo	Valor máximo
$R + G + B$	Res1 (Figura A1 - anexo)	74	409
$\frac{NIR}{R + G + B}$	Res2 (Figura A2 - anexo)	0.071429	0.424658
$\left(\frac{NIR}{R}\right)^{-2}$	Res3 (Figura A3 - anexo)	0.167355	14.271604

Com estes valores foram verificadas as condições para diferentes conjuntos de índices de acordo com a Tabela 6.

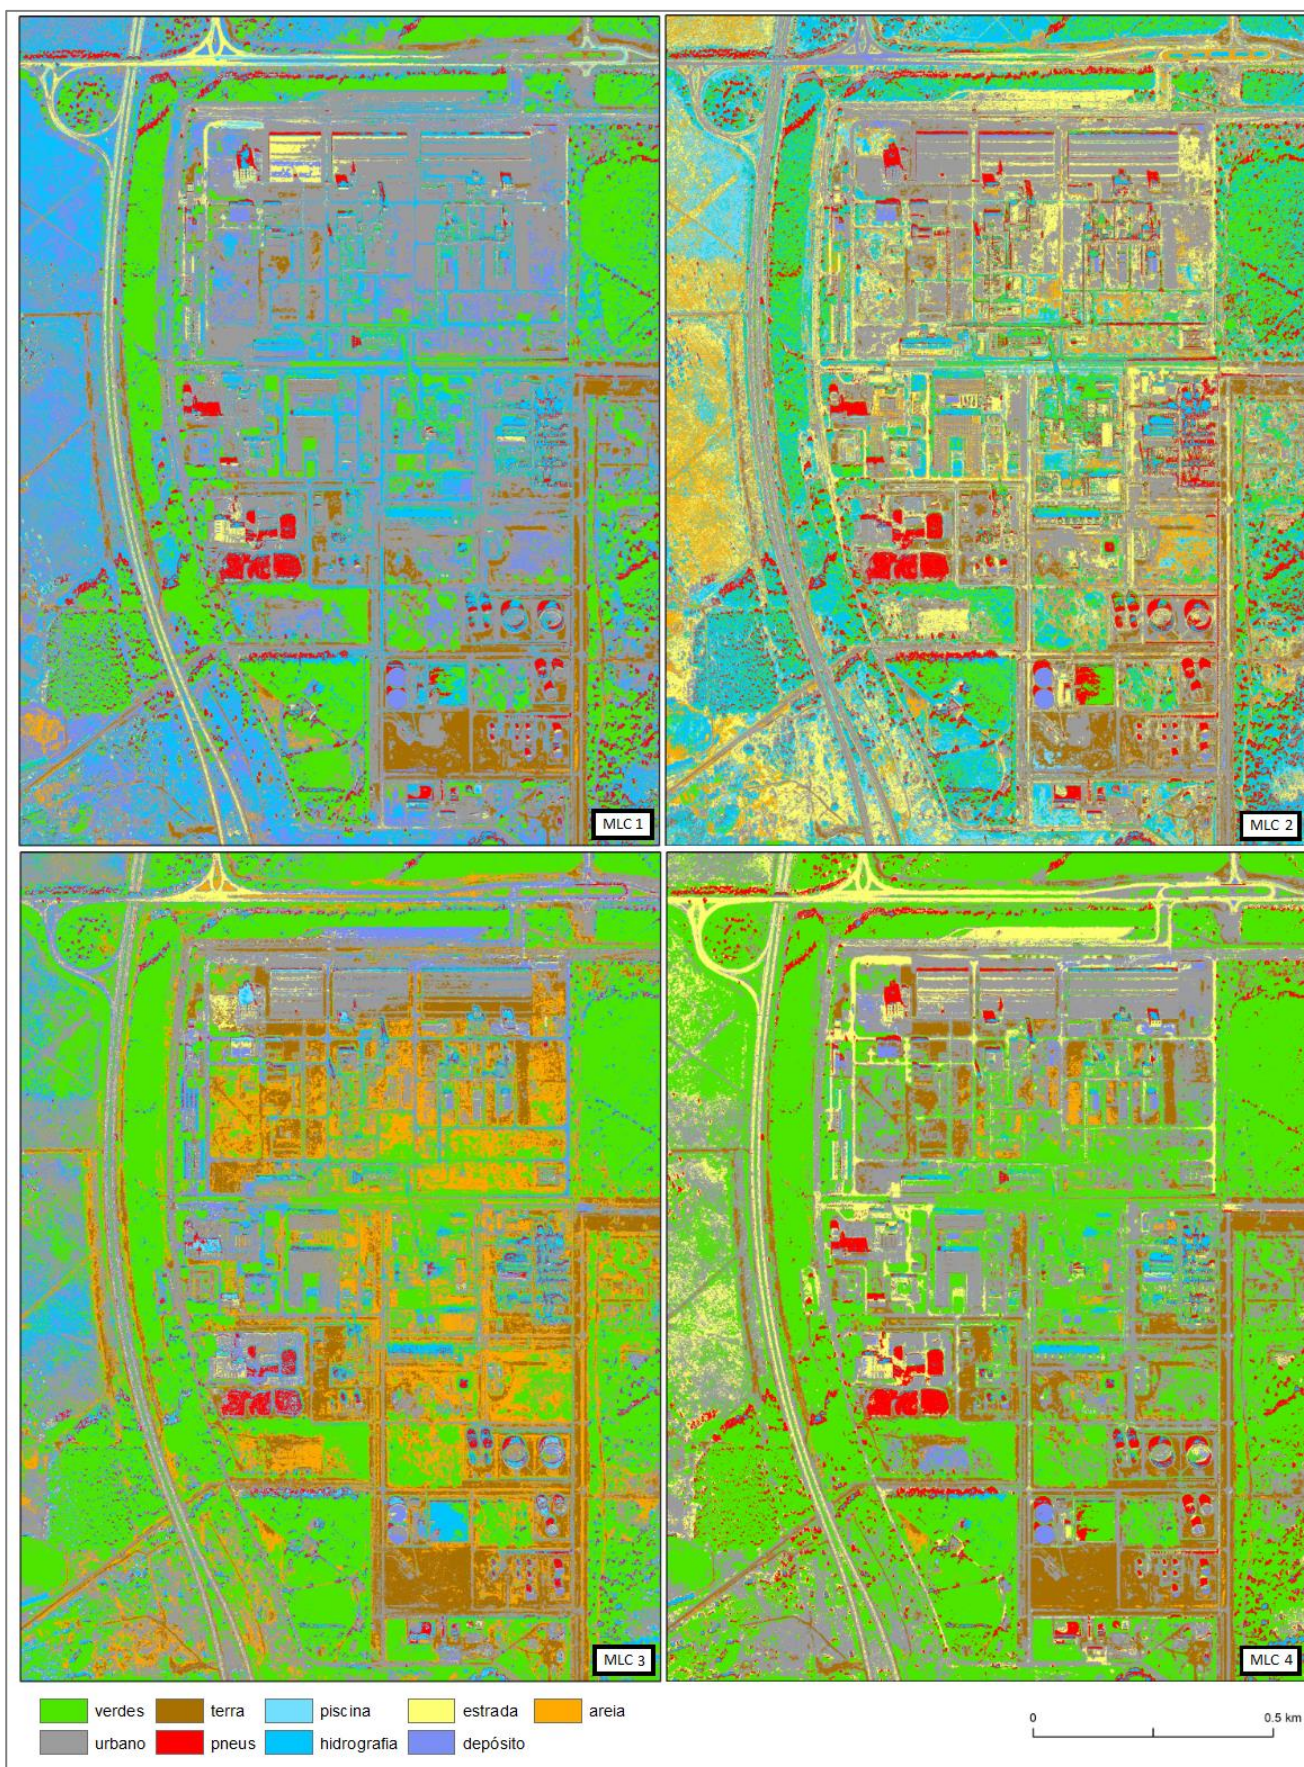
**Tabela 6 - Condições para índices calculados.**

Condições			Nome <i>Output</i>
Res1	Res2	-	Cond1
Res1	Res3	-	Cond2
Res2	Res3	-	Cond3
Res1	Res2	Res3	Cond4

Feito isto foram criadas assinaturas espectrais para cada condição criada, e posteriormente aplicado o MLC.

Até aqui foi realizada uma primeira análise com o classificador MLC para cada resultado obtido no passo anterior, para perceber a qualidade da classificação através de métodos *pixel-a-pixel*. Como se pode observar na Figura 11, o resultado não foi satisfatório pois a classe de pneus não foi automaticamente identificada e diferenciada das restantes, em qualquer uma das condições aplicadas. Neste caso as áreas de pneus tinham todas sido identificadas nas áreas de treino e esperava-se que não apresentassem falsos positivos na classificação.






**Figura 11 - Resultados obtidos do MLC.**



Desta forma procedeu-se para uma classificação de imagens diferente, utilizando o *software* IDRISI e introduzindo os restantes índices calculados (Tabela 3). Para isso foi gerada uma combinação dos resultados dos três índices de acordo com a Análise de Componentes Principais (ACP), tendo a combinação dos 3 mostrado melhor resultado visual (Figura 12). Esta é uma técnica de análise multivariada que tem como objetivo transformar um conjunto de variáveis. Esta imagem permitiu uma visão clara das classes existentes no terreno de modo a melhorar a visualização das classes na imagem ainda no *software* ArcMap que foi posteriormente inserida no *software* IDRISI. Este resultado foi utilizado como base para a segmentação orientada ao objeto.



**Figura 12 – Primeira componente principal dos três índices (água e vegetação).**


Foram escolhidos os parâmetros de segmentação, através do método tentativa erro com recurso da ferramenta *Segmentation* (IDRISI). Numa primeira fase apenas foram utilizados os 3 índices calculados inicialmente, e as 4 bandas originais do ortofotomapa (Tabela 7).

***Tabela 7 - Parâmetros de segmentação no IDRISI Selva.***

<i>Inputs</i>	Largura da janela	Tolerância de similaridade	Peso do fator média	Peso do fator variância	Nomes <i>Outputs</i>
Res1, Res2, Res3	3	10	0,5	0,5	Segmentação 1
Res1, Res2, Res3, Banda R, Banda G, Banda B, Banda NIR	3	10	0,5	0,5	Segmentação 2
Res1, Res2, Res3, Banda R, Banda G, Banda B, Banda NIR	3	20	2	2	Segmentação 3
Res1, Res2, Res3	3	20	2	2	Segmentação 4

Dados os resultados obtidos da segmentação (Figura 13) foram escolhidos os parâmetros utilizados pela segmentação 3 e segmentação 4 por apresentarem uma melhor distribuição e proporção entre os segmentos, os quais se enquadravam melhor nas áreas da imagem.





**Figura 13 – Resultados das segmentações 1, 2, 3 e 4 de acordo com a Tabela 7.**



De seguida foram criadas as áreas de treino com a ferramenta *Segtrain*. Neste foi utilizado o ficheiro segmentado no passo anterior, juntamente com o compósito inicial dos três índices (o ficheiro ACP). Esta ferramenta serviu para criar classes de treino. Na Tabela 8 estão apresentadas as classes escolhidas e o número total de segmentos selecionados. A escolha das classes deu-se principalmente pela semelhança espectral que os pneus apresentam, levando à criação de uma classe de água e outra de sombras. As sombras são importantes em dois aspetos opostos, a forma ou contorno de uma sombra pode dar uma impressão da vista de perfil dos objetos, e objetos dentro das sombras refletem pouca luz tornando-se difíceis de distinguir numa imagem (Lillesand & Kiefer, 1979).

***Tabela 8 - Classes de área de treino.***

<i>Inputs</i>	Classes	Nº total de segmentos escolhidos
Segmentação 3	Pneus	251
ACP	Edifícios	
	Depósito	
	Sombras	
	Estrada	
	Hidrografia	
	Areia	

Após criado o ficheiro, foi utilizada a ferramenta *MakeSIG* onde foi gerada uma assinatura espectral com a informação das áreas de treino, simultaneamente com os *inputs* iniciais.

Por fim foi aplicado o algoritmo *MaxLike* que permitiu utilizar o ficheiro de assinaturas espectrais criado no passo anterior, por forma a classificar a imagem para obter o resultado final da classificação. No capítulo 5 estão apresentados os resultados finais destas segmentações.

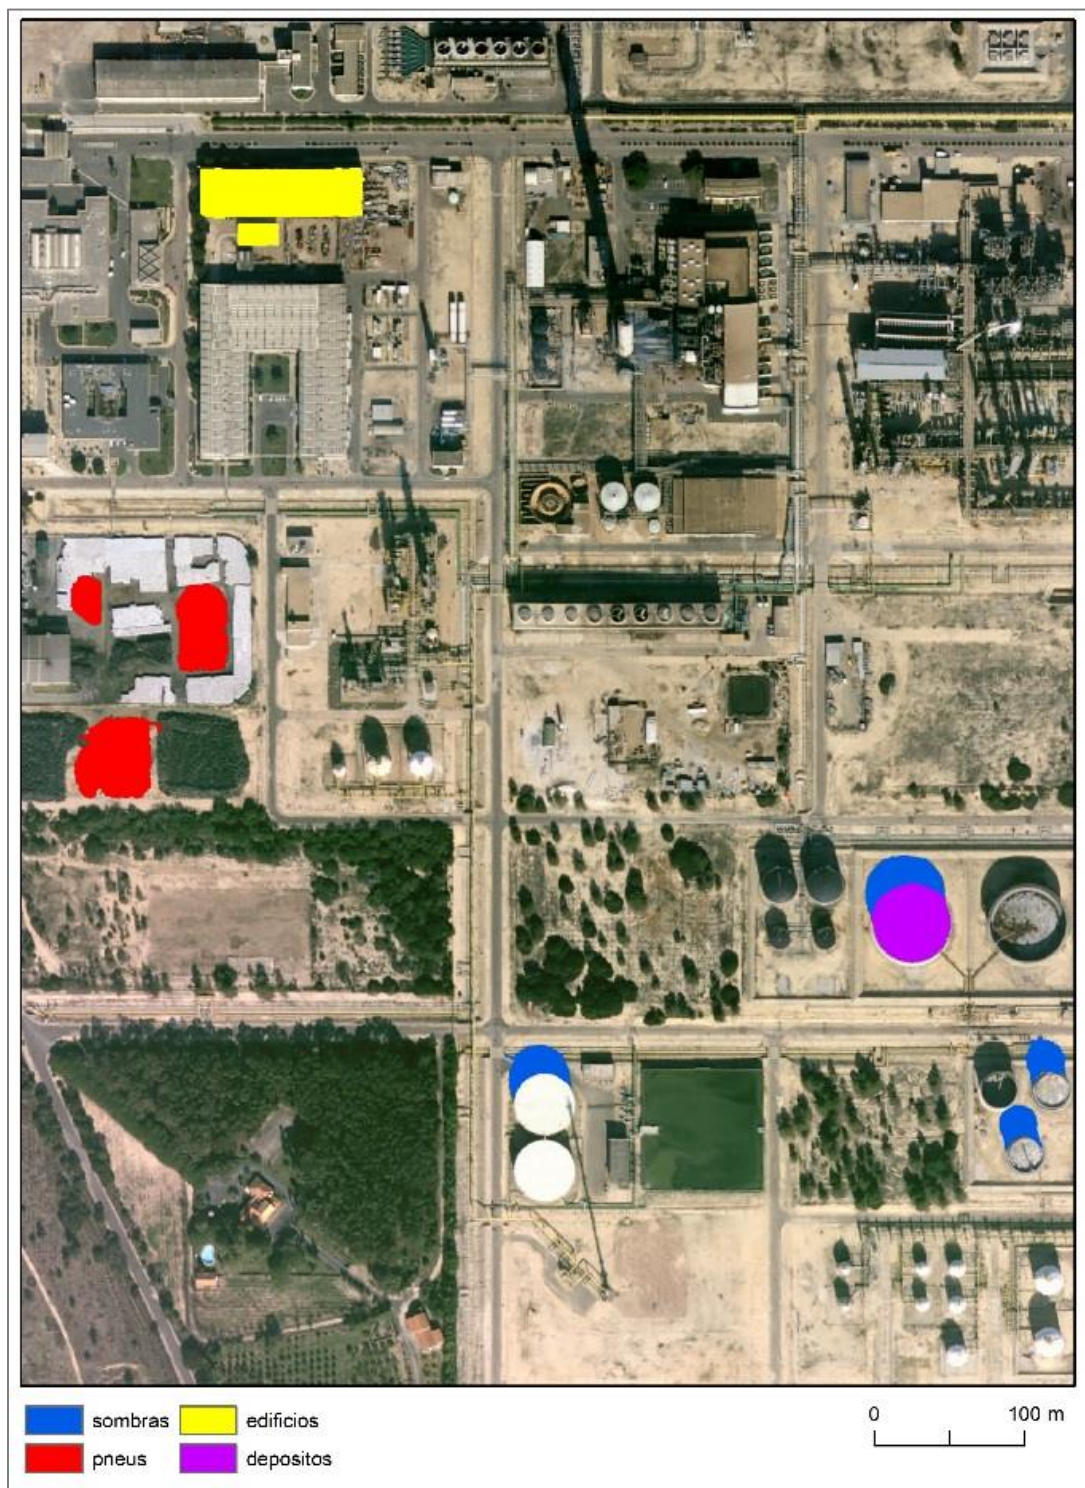
Uma vez que este método apresentou uma boa classificação, nomeadamente a identificação da classe dos pneus, foram introduzidos os restantes índices calculados no início deste estudo, para verificar se as classificações apresentariam melhores resultados. Assim foram aplicados os mesmos parâmetros de entrada na segmentação de imagem, e foi também utilizado o

ficheiro resultante do ACP como imagem de base. Na Tabela 9 estão apresentadas as combinações de índices realizadas.

**Tabela 9 – Parâmetros de segmentação no IDRISI Selva.**

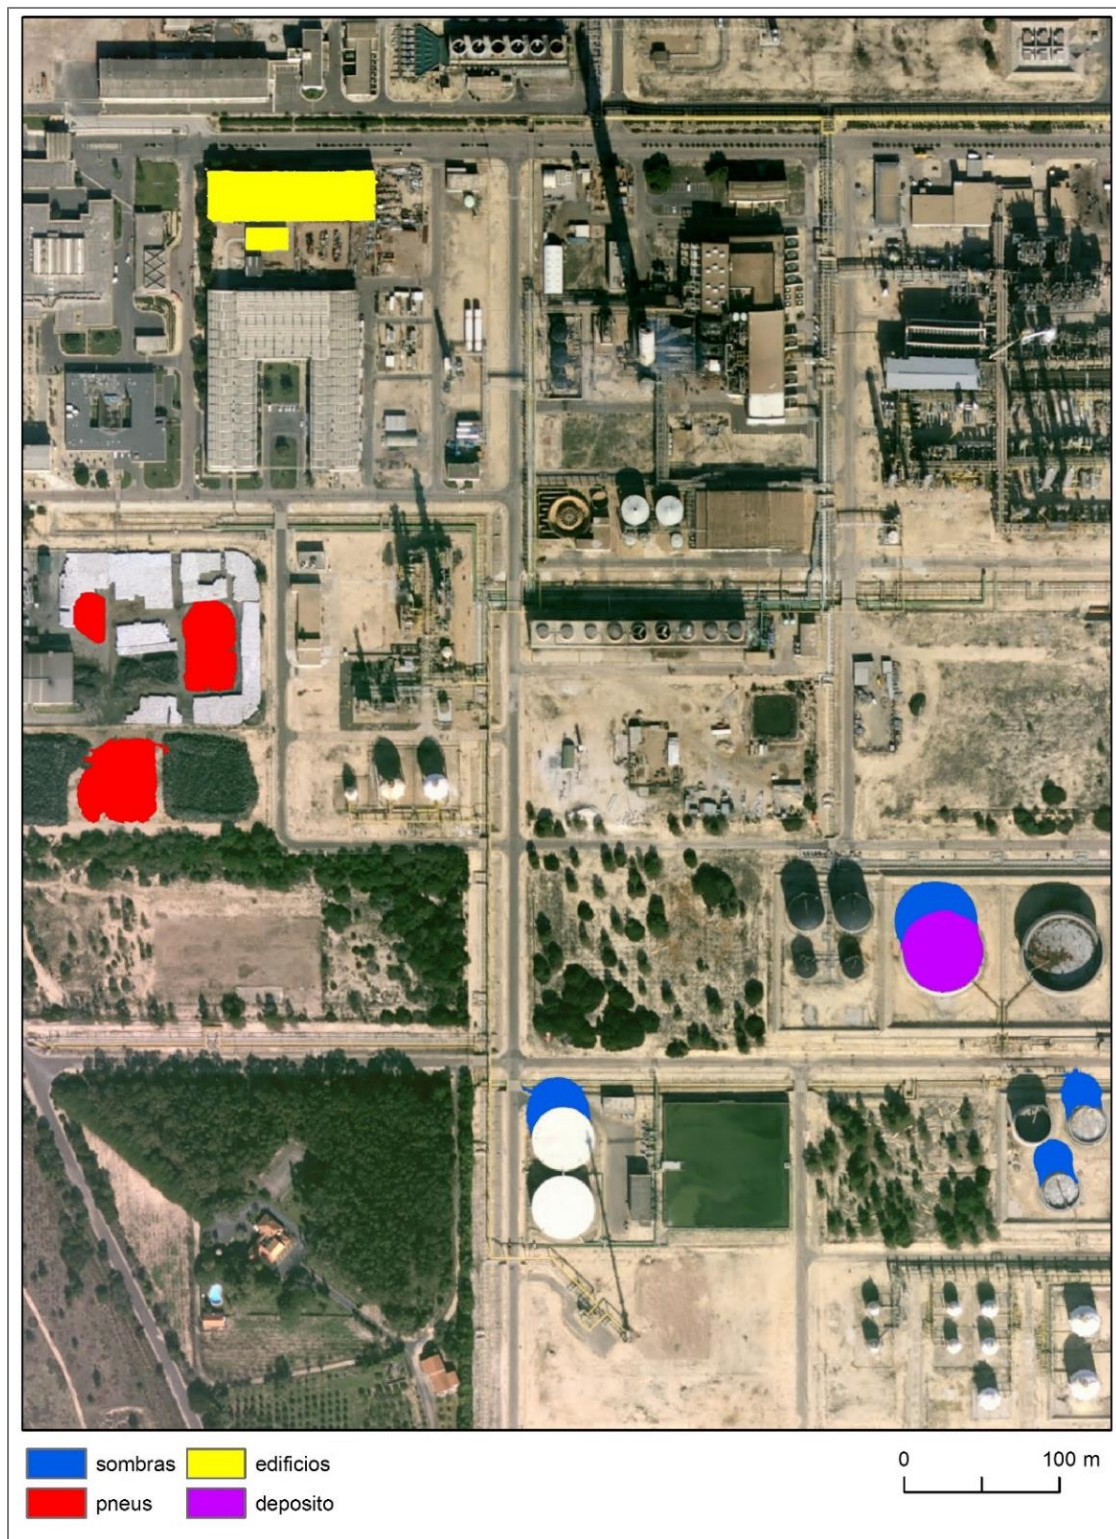
<i>Inputs</i>	Nº total de segmentos escolhidos	Largura da janela	Tolerância de similaridade	Peso do fator média	Peso do fator variância	Nomes <i>Outputs</i>
Res1, Res2, Res3, Banda R, Banda G, Banda B, Banda NIR, NDVI	272	3	10	2	2	Segmentação 5
Res1, Res2, Res3, Banda R, Banda G, Banda B, Banda NIR, NDWI	281					Segmentação 6 (Figura A4 – anexo)
Res1, Res2, Res3, Banda R, Banda G, Banda B, Banda NIR, NDWI <sub>2</sub>	282					Segmentação 7 (Figura A5 – anexo)
Res1, Res2, Res3, Banda R, Banda G, Banda B, Banda NIR, NDVI, NDWI	276					Segmentação 8
Res1, Res2, Res3, Banda R, Banda G, Banda B, Banda NIR, NDVI, NDWI <sub>2</sub>	282					Segmentação 9 (Figura A6 – anexo)
Res1, Res2, Res3, Banda R, Banda G, Banda B, Banda NIR, NDWI, NDWI <sub>2</sub>	275					Segmentação 10 (Figura A7 – anexo)
Res1, Res2, Res3, Banda R, Banda G, Banda B, Banda NIR, NDVI	369					Segmentação 11 (Figura A8 – anexo)

Uma vez que para cada segmentação nunca tem o mesmo número de segmentos nem segmentos da mesma dimensão, tentou-se utilizar sempre as mesmas áreas para a escolha das classes de treino. As Figuras 14 e 15 constituem dois exemplos das áreas escolhidas para a segmentação 3 (onde foram criadas as primeiras áreas de treino) e a segmentação 5, respetivamente.



*Figura 14 - Áreas de treino da segmentação 3.*





**Figura 15 - Áreas de treino da segmentação 5.**

Como se pode observar em ambas as imagens, as áreas de segmentação foram muito semelhantes em todas as combinações, para testar da melhor maneira a aplicabilidade dos diferentes índices.

## 5. Resultados e discussão

No seguimento da metodologia apresentada nesta dissertação, serão apresentados os resultados finais das classificações realizadas no *software* IDRISI.


Na Figura 16 pode-se observar a classificação resultante da segmentação mais simples que foi realizada, onde foram utilizadas apenas as bandas originais do ortofotomapa e os 3 índices propostos inicialmente (segmentação 3). Como se pode verificar a classe de pneus foi bem identificada e maioritariamente separada das restantes classes. Pode-se deduzir que as sombras dos depósitos ficaram fora da classe dos pneus, o que demonstra que este índice é uma boa base para uma classificação automática.



**Figura 16 - Classificação resultante da segmentação 3.**




Após adicionar índices ao resultado apresentado anteriormente, pode-se verificar que houve um aumento de falsos positivos em todos eles, tornando as classificações menos exatas como se pode deduzir dos resultados da segmentação 5 onde foi introduzido o índice de vegetação (Figura 17). As sombras passaram a incluir a classe dos pneus, apesar de terem sido identificadas numa área de treino própria.



*Figura 17 - Classificação resultante da segmentação 5.*



Verifica-se a mesma situação quando aplicado apenas o índice de vegetação e apenas um índice de água à segmentação inicial (Figura 18). Desta vez a área de pneus encontra-se mais preenchida, mas continuam a aparecer nesta classe algumas sombras de depósitos e vegetação.



*Figura 18 - Classificação resultante da segmentação 8.*



Como se pode verificar dos resultados apresentados, nem todas as classificações representam bem a classe dos pneus, existindo sempre falsos positivos associados. Neste sentido qualquer uma das classificações apresentou resultados positivos no que respeita a encontrar a classe dos pneus, mas esta classificação poderia não ser suficiente para o propósito do estudo.

Para uma avaliação quantitativa dos resultados, foram geradas matrizes de confusão para as três segmentações acima apresentadas. Para o efeito foram gerados 200 pontos de amostra através de uma estratificação aleatória (para garantir amostras em ambas as classes). De acordo com os valores obtidos (Tabela 10), pode-se concluir que apesar de visualmente a segmentação mais simples (segmentação 3) ter o melhor desempenho, na verdade é a que apresenta um valor Kappa abaixo do esperado com apenas 0,58. Já as segmentações 5 e 8, apresentaram um índice Kappa de 0,85, tornando o seu resultado aceitável.

***Tabela 10 – Resultados da Matriz de Confusão de 3 segmentações.***

Segmentação	Classe	Não pneus	Pneus	Total	Exatidão do Utilizador	Kappa
3	Não pneus	98	40	138	0,71	0
	Pneus	2	60	62	0,97	0
	Total	100	100	200	0	0
	Exatidão do Produtor	0,98	0,6	0	0,79	0
	Kappa	0	0	0	0	0,58
5	Não pneus	93	8	101	0,92	0
	Pneus	7	92	99	0,93	0
	Total	100	100	200	0	0
	Exatidão do Produtor	0,93	0,92	0	0,93	0
	Kappa	0	0	0	0	0,85
8	Não pneus	96	11	107	0,90	0
	Pneus	4	89	93	0,96	0
	Total	100	100	200	0	0
	Exatidão do Produtor	0,96	0,89	0	0,925	0
	Kappa	0	0	0	0	0,85

Já a exatidão do utilizador expressa o ponto de vista do “consumidor” do mapa. Basicamente indica com que frequência a classe no mapa estará realmente presente na realidade, i.e., confiabilidade. Neste caso percebemos que a segmentação 3 é a que apresenta melhores resultados para a classe dos pneus (0,97) podendo ser uma alternativa viável para a identificação de áreas passíveis de vigilância, visto assentar no procedimento mais simples das três.

## 6. Conclusão

A utilização de técnicas de DR tem-se mostrado fundamental para uma melhor percepção da dinâmica das atividades humanas sobre os ecossistemas, permitindo investigações mais detalhadas e precisas.

A classificação orientada ao objeto mostrou ser ideal no processamento de imagens sobre o uso e ocupação do solo através da utilização de dados resultantes das interações entre a REM e o objeto de estudo, podendo introduzir novas variáveis como a forma do objeto, complementando estudos das mais diversas áreas da geografia, engenharia entre outras.

A utilização do algoritmo *Maximum Likelihood Classification* no software ArcGIS, caracterizou-se por uma mistura espectral muito grande entre as classes temáticas, havendo dificuldade em discriminar certas classes como o caso dos pneus, a classe de maior importância para o presente estudo. A classificação ao nível do *pixel* mostrou-se inviável face aos objetivos deste trabalho.

Ao introduzir a classificação orientada ao objeto foi possível obter resultados positivos, identificando a classe de pneus e discriminando-a das restantes. Apesar dos testes realizados e a introdução de novos índices a cada cálculo, verificou-se que com uma combinação de índices mais simples é possível obter uma classificação adequada da classe dos pneus.

Deve-se ter em conta que um maior detalhe nas fotografias utilizadas nomeadamente a utilização de outra escala ou até mesmo de outro tipo de imagens, poderia permitir obter resultados melhores onde os pneus estariam mais definidos, destacando-se das restantes classes de ocupação do solo, reduzindo o ruído produzido, ou até mesmo poderiam os índices aplicados mostrar melhores resultados. Com isto conclui-se que a introdução de novos índices poderia orientar os resultados de acordo com a sua informação disponível e a sua qualidade.

Dada a falta de disponibilidade de imagens com áreas de pneus ao ar livre, foi impossível aplicar este método a novas áreas, não se podendo avaliar a sua replicabilidade.

Com isto, não é possível prever se este método não se tornou sensível à área de estudo, não sendo possível prever se a sua aplicabilidade numa nova área terá o mesmo resultado, pois estes irão depender não só das imagens a utilizar, mas também do software e das classes de ocupação e uso do solo.

No que diz respeito ao processo e desempenho dos *softwares*, verificou-se o *software* IDRISI apresenta algumas limitações durante a criação de áreas de treino, pelo que a utilização de outro *software* também poderia conduzir a resultados melhores.

Esta análise exploratória no que diz respeito a estes estudos deve ser continuada de forma a se aprimorarem os resultados, explorando novas áreas de estudo e a utilização de diferentes tipos de imagens, com maior resolução espacial e espectral. Apesar disso, conclui-se que os resultados foram positivos e que poderão ser melhorados e utilizados noutros projetos.

## 7. Referências Bibliográficas

- Agência Portuguesa do Ambiente (APA). (2020). Pneus Usados. Retrieved October 23, 2020, from <https://apambiente.pt/index.php?ref=16&subref=84&sub2ref=197&sub3ref=287>
- Antunes, A. (2003). Classificação de ambiente ciliar baseada em orientação a objeto em imagens de alta resolução espacial.
- Baatz, M., & Schape, A. (2000). Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. *Angew. Geogr. Info. Verarbeitung*, Wichmann-Verlag, Heidelberg, 12–23.
- Biziak, L. D. (2017). Sustentabilidade urbana : avaliação da qualidade ambiental do setor central de, (May). <https://doi.org/10.13140/RG.2.2.31221.99045>
- Blaschke, T., & Kux, H. (2005). Sensoriamento remoto e SIG avançados: novos sistemas sensores, métodos inovadores. *Oficina de Textos*. Retrieved from <https://books.google.pt/books?id=XIWSAAAACAAJ>
- Blaschke, T., Lang, S., & Eds, G. J. H. (2001). *Lecture Notes in Geoinformation and Cartography*. Retrieved from Blaschke
- Chenari, A., Erfanifard, Y., Dehghani, M., Pourghasemi, H. R., & ... (2017). Woodland mapping at Single-Tree Levels Using Object-oriented Classification of Unmanned Aerial Vehicle ( UAV ) Images, XLII(October), 7–10.
- Congalto, R., & Green, K. (1999). *Assessing the Accuracy of Remotely Sensed Data - Principles and Practices*.
- Contemporâneo, P.-B. de D. P. (2020). BI de Portugal. Retrieved October 23, 2020, from <https://www.pordata.pt/Portugal/>
- Crósta, A. P. (1992). *Processamento digital de imagens de sensoriamento remoto*, 170p.
- DGT. (n.d.). Quem somos. Retrieved from <https://www.dgterritorio.gov.pt/dgt/quem-somos>
- Eastman, J. R. (2012). Chapter Thirteen : Decision Support: Decision Strategy Analysis. *IDRISI Selva Manual*, (January), 126–146.
- Eaton, D. (2007). *Remote Sensing and Clandestine Tire Pile Identification*.

EPortugal. (n.d.). Direção-Geral do Território. Retrieved from <https://eportugal.gov.pt/entidades/direcao-geral-do-territorio>

ESRI. (n.d.). About ESRI - The Science of Where. Retrieved from [https://www.esri.com/en-us/about/about-esri/overview?rmedium=www\\_esri\\_com\\_EtoF&rsource=https%3A%2F%2Fwww.esri.com%2Fen-us%2Fabout](https://www.esri.com/en-us/about/about-esri/overview?rmedium=www_esri_com_EtoF&rsource=https%3A%2F%2Fwww.esri.com%2Fen-us%2Fabout)

Fonseca, A. D., & Fernandes, J. C. (2004). Detecção remota. LIDEL (BRASIL). Retrieved from <https://books.google.pt/books?id=VCCXPgAACAAJ>

Franklin, E. de M. (n.d.). Introdução à radiação térmica. Retrieved from [http://www.fem.unicamp.br/~franklin/EM524/aula\\_em524\\_pdf/aula-26.pdf](http://www.fem.unicamp.br/~franklin/EM524/aula_em524_pdf/aula-26.pdf)

Garofalo, D., & Wobber, F. J. (1974). Solid waste and remote sensing, 40, 45–59.

Glanville, K., & Chang, H. C. (2015). Remote sensing analysis techniques and sensor requirements to support the mapping of illegal domestic waste disposal sites in Queensland, Australia. *Remote Sensing*, 7(10), 13053–13069. <https://doi.org/10.3390/rs71013053>

Gomes, M. F., & Maillard, P. (2016). Detection of Tree Crowns in Very High Spatial Resolution Images Detection of Tree Crowns in Very High Spatial Resolution Images, (June). <https://doi.org/10.5772/62122>

Haralick, R. M., & Shapiro, L. G. (1985). Image segmentation techniques. *Computer Vision, Graphics, and Image Processing*, 29(1), 100–132. [https://doi.org/https://doi.org/10.1016/S0734-189X\(85\)90153-7](https://doi.org/https://doi.org/10.1016/S0734-189X(85)90153-7)

Hay, G. J., & Castilla, G. (2008). Geographic object-based image analysis (GEOBIA): A new name for a new discipline. *Lecture Notes in Geoinformation and Cartography*. [https://doi.org/10.1007/978-3-540-77058-9\\_4](https://doi.org/10.1007/978-3-540-77058-9_4)

Hussain, M., Chen, D., Cheng, A., Wei, H., & Stanley, D. (2013). Change detection from remotely sensed images: From pixel-based to object-based approaches. *ISPRS Journal of Photogrammetry and Remote Sensing*, 80(June), 91–106. <https://doi.org/10.1016/j.isprsjprs.2013.03.006>

Image Bands. (2019). Retrieved from

[http://gsp.humboldt.edu/OLM/Courses/GSP\\_216\\_Online/lesson3-1/bands.html](http://gsp.humboldt.edu/OLM/Courses/GSP_216_Online/lesson3-1/bands.html)

InterPLAST. (2020). Porque é que a reciclagem de pneus ajuda a evitar a propagação de mosquitos? Retrieved October 21, 2020, from <https://www.interplast.pt/Artigos/312385-Porque-e-que-a-reciclagem-de-pneus-ajuda-a-evitar-a-propagacao-de-mosquitos.html>

Ke, Y., & Quackenbush, L. J. (2011). A review of methods for automatic individual tree-crown detection and delineation from passive remote sensing. *International Journal of Remote Sensing*. <https://doi.org/10.1080/01431161.2010.494184>

Korpela, I. (2004). Individual Tree Measurements by Means of Digital Aerial Photogrammetry.

Kux, B. R. H. (2009). Classificação Orientada a Objeto para Mapeamento do Uso do Solo – Métodos de Análise de Expansão Urbana, (January).

Labs, C. (2020). TerrSet 2020 Now Shipping! Retrieved from <https://clarklabs.org/terrset-2020-landing-page/>

Leckie, D., Gougeon, F., Hill, D., Quinn, R., Armstrong, L., & Shreenan, R. (2003). Combined high-density lidar and multispectral imagery for individual tree crown analysis. *Canadian Journal of Remote Sensing*, 29(5), 633–649. <https://doi.org/10.5589/m03-024>

Lillesand, T. M., & Kiefer, R. W. (1979). Remote sensing and image interpretation. *Remote sensing and image interpretation*. <https://doi.org/10.2307/634969>

López, J. P. A. (2012). Object-based methods for mapping and monitoring of urban trees with multitemporal image analysis. *Faculty of Geo-Information Science and Earth Observation*, 176.

Marpu, P. (2009). Geographic object-based image analysis.

Martins, J. (2015). Detecção Remota na Avaliação das Alterações da Cobertura do Solo no Parque Nacional da Peneda-Gerês João Paulo Correia Martins Detecção Remota na Avaliação das Alterações da Cobertura do Solo no Parque Nacional da Peneda-Gerês.

McFeeters, S. K. (1996). The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*, 17(7), 1425–1432. <https://doi.org/10.1080/01431169608948714>

Miranda, P. (2004). Aplicação da detecção remota em inventário florestal.

- Molenaar, M. (1998). The fuzzy spatial extent of objects identified with remote sensing and photo-interpretation.
- Osório, H., Neto, M., Silva, S., Marques, F., Alves, M., Silva, A., & Zé-Zé, L. (2018). Detection of the Invasive Mosquito Species *Aedes (Stegomyia) albopictus* (Diptera : Culicidae) in Portugal, 1–9. <https://doi.org/10.3390/ijerph15040820>
- Pacievitch, T. (2020). Geografia de Portugal. Retrieved October 23, 2020, from <https://www.infoescola.com/geografia/geografia-de-portugal/>
- Page, R., Lavender, S., Thomas, D., Berry, K., Stevens, S., Haq, M., ... Brockie, I. (2020). Identification of tyre and plastic waste from combined copernicus sentinel-1 and-2 data. *Remote Sensing*, 12(17), 1–14. <https://doi.org/10.3390/rs12172824>
- Quinlan, B., Huybrechts, C., Schmidt, C., & Skiles, J. W. (2006). Detecting waste tire piles using high-resolution satellite imagery and an image processing model in two regions of California. *American Society for Photogrammetry and Remote Sensing - Annual Conference of the American Society for Photogrammetry and Remote Sensing 2006: Prospecting for Geospatial Information Integration*, 2, 1137–1143.
- Quinlan, B. L., & Foschi, P. G. (2012). Identification of waste tires using high-resolution multispectral satellite imagery. *Photogrammetric Engineering and Remote Sensing*, 78(5), 463–471. <https://doi.org/10.14358/PERS.78.5.463>
- Radiação Eletromagnética. (2020). Retrieved from <http://www.fq.pt/luz/radiacao-eletromagnetica>
- Richards, J. A., & Jia, X. (2006). Remote sensing digital image analysis: An introduction. *Remote Sensing Digital Image Analysis: An Introduction*, (January 2006), 1–439. <https://doi.org/10.1007/3-540-29711-1>
- Salleh, J. B., & Tsudagawa, M. (2002). Classification of industrial disposal illegal dumping site images by using spatial and spectral information together (Vol. 1, pp. 559–563 vol.1). <https://doi.org/10.1109/IMTC.2002.1006903>
- SNS. (n.d.). *Aedes albopictus*. Retrieved November 1, 2020, from <https://www.dgs.pt/paginas-de-sistema/saude-de-a-a-z/aedes-albopictus-mosquito.aspx>
- Tilton, J. C., Marchisio, G., Koperski, K., & Datcu, M. (2002). Image information mining utilizing



hierarchical segmentation. In IEEE International Geoscience and Remote Sensing Symposium (Vol. 2, pp. 1029–1031 vol.2). <https://doi.org/10.1109/IGARSS.2002.1025765>

valorpneu. (2020). TUDO O QUE PRECISA DE SABER SOBRE RECAUCHUTAGEM. Retrieved October 23, 2020, from <https://recauchutagem.valorpneu.pt>

Willhauck, G. (2000). Comparison of object oriented classification techniques and standard image analysis for the use of change detection between SPOT multispectral satellite images and aerial photos. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives, 33(January 2000), 35–42.

## 8. Anexos

Figura A1 – Resultado res1 de acordo com a Tabela 5.





Figura A2 – Resultado res2 de acordo com a Tabela 5.



Figura A3 – Resultado res3 de acordo com a Tabela 5.





Figura A4 – Classificação resultante da segmentação 6.






Figura A5 – Classificação resultante da segmentação 7.






Figura A6 – Classificação resultante da segmentação 9.





Figura A7 – Classificação resultante da segmentação 10.






Figura A8 – Classificação resultante da segmentação 11.

